

O USO DA INTELIGÊNCIA ARTIFICIAL NA MEDICINA MODERNA



Rfb
Editora

O USO DA INTELIGÊNCIA ARTIFICIAL NA MEDICINA MODERNA



Todo o conteúdo apresentado neste livro é de responsabilidade do(s) autor(es).
Esta obra está licenciada com uma Licença Creative Commons Atribuição-SemDerivações 4.0 Internacional.

Nossa missão é a difusão do conhecimento gerado no âmbito acadêmico por meio da organização e da publicação de livros científicos de fácil acesso, de baixo custo financeiro e de alta qualidade!

Nossa inspiração é acreditar que a ampla divulgação do conhecimento científico pode mudar para melhor o mundo em que vivemos!

Equipe RFB Editora

Luciano Roberto da Silva Leal

O USO DA INTELIGÊNCIA ARTIFICIAL NA MEDICINA MODERNA

1ª Edição

Belém-PA
RFB Editora
2023

© 2023 Edição brasileira
by RFB Editora
© 2023 Texto
by Autor
Todos os direitos reservados

RFB Editora
CNPJ: 39.242.488/0001-07
www.rfbeditora.com
adm@rfbeditora.com
91 98885-7730
Av. Governador José Malcher, nº 153, Sala 12, Nazaré, Belém-PA,
CEP 66035065

Editor-Chefe
Prof. Dr. Ednilson Souza
Diagramação e capa
Worges Editoração
Imagem da capa
Canva.com

Revisão de texto
Autor
Bibliotecária
Janaina Karina Alves Trigo Ramos
Produtor editorial
Nazareno Da Luz

Catlogação na publicação

RFB Editora



U86

O uso da inteligência artificial na medicina moderna / Luciano Roberto da Silva Leal. – Belém: RFB, 2023.

Livro em PDF

64 p.

ISBN: 978-65-5889-454-4

DOI: 10.46898/rfb.202a8af1-9431-4072-b845-1625d70ad6bf

1. Medicina. I. Leal, Luciano Roberto da Silva. II. Título.

CDD 610

Índice para catálogo sistemático

I. Medicina e Saúde.

Conselho Editorial

Prof. Dr. Ednilson Sergio Ramalho de Souza - UFOPA
(Editor-Chefe)

Prof. Dr. Laecio Nobre de Macedo-UFMA

Prof^a. Ma. Rayssa Feitoza Felix dos Santos-UFPE

Prof. Me. Otávio Augusto de Moraes-UEMA

Prof. Dr. Aldrin Vianna de Santana-UNIFAP

Prof^a. Ma. Luzia Almeida Couto-IFMT

Prof^a. Dr^a. Raquel Silvano Almeida-Unespar

Prof. Me. Luiz Francisco de Paula Ipolito-IFMT

Prof. Me. Fernando Vieira da Cruz-Unicamp

Prof. Dr. Carlos Erick Brito de Sousa-UFMA

Prof^a. Dr^a. Ilka Kassandra Pereira Belfort-Faculdade Laboro

Prof^a. Dr. Renata Cristina Lopes Andrade-FURG

Prof. Dr. Elias Rocha Gonçalves-IFF

Prof. Dr. Clézio dos Santos-UFRRJ

Prof. Dr. Rodrigo Luiz Fabri-UFJF

Prof. Dr. Manoel dos Santos Costa-IEMA

Prof^a. Ma. Adriana Barni Truccolo-UERGS

Prof. Me. Pedro Augusto Paula do Carmo-UNIP

Prof.^a Dr^a. Isabella Macário Ferro Cavalcanti-UFPE

Prof. Me. Alisson Junior dos Santos-UEMG

Prof. Me. Raphael Almeida Silva Soares-UNIVERSO-SG

Prof. Dr. Rodolfo Maduro Almeida-UFOPA

Prof. Me. Tiago Silvio Dedoné-Faccrei

Prof. Me. Fernando Francisco Pereira-UEM

Prof. Dr. Deivid Alex dos Santos-UEL

Prof. Me. Antonio Santana Sobrinho-IFCE

Prof.^a Dr.^a. Maria de Fatima Vilhena da Silva-UFPA

Profa. Dra. Dayse Marinho Martins-IEMA

Prof. Me. Darlan Tavares dos Santos-UFRJ

Prof. Dr. Daniel Tarciso Martins Pereira-UFAM

Prof.^a Dr.^a. Elane da Silva Barbosa-UERN

Prof. Dr. Piter Anderson Severino de Jesus-Université Aix Marseille

SUMÁRIO

SOBRE O AUTOR	9
APRESENTAÇÃO	11
CAPÍTULO 1	
INTRODUÇÃO	13
CAPÍTULO 2	
INTELIGÊNCIA ARTIFICIAL NA MEDICINA.....	25
CAPÍTULO 3	
APLICAÇÕES DE INTELIGÊNCIA ARTIFICIAL NA ÁREA DA SAÚDE	35
CAPÍTULO 4	
CONCLUSÃO.....	49
REFERÊNCIAS.....	52
ÍNDICE REMISSIVO.....	62

SOBRE O AUTOR

O autor do livro é Mestre em Engenharia da Computação pela Universidade de Pernambuco. A inspiração do autor em escrever livros é a busca pela construção do conhecimento de tal forma que possa ser aplicado, compartilhado e expandido. Desde de 2022 escreve e publica livros na área de tecnologia, inteligência artificial, inovação e empreendedorismo.

APRESENTAÇÃO

As tecnologias médicas baseadas em inteligência artificial estão evoluindo rapidamente para soluções aplicáveis à prática clínica. Inundados com grandes volumes de dados de saúde e responsabilidades crescentes, os médicos estão lutando para encontrar tempo para acompanhar as evidências médicas mais recentes e ainda fornecer cuidados centrados no paciente. Ao aplicar tecnologias de aprendizado de máquina aos mais recentes dados biomédicos e registros eletrônicos de saúde, os profissionais de saúde podem extrair rapidamente informações precisas, relevantes e baseadas em evidências que foram selecionadas por profissionais médicos. Algumas ferramentas de suporte à decisão clínica com IA ajudam profissionais de saúde no tratamento e diagnóstico.

CAPÍTULO 1

INTRODUÇÃO

1.1 MEDICINA MODERNA

A medicina moderna enfrenta o desafio de adquirir, analisar e aplicar uma quantidade imensa de conhecimentos para resolver problemas clínicos complexos. A produção de quantidades massivas de informação clínica e biológica do dia-a-dia médico faz com que os limites humanos para a sua análise sejam facilmente ultrapassados levando a uma dependência cada vez maior das máquinas. Neste sentido, as técnicas de inteligência artificial e de aprendizagem de máquina têm o potencial de transformar os cuidados de saúde ajudando a processar esta grande quantidade de informação e retirando novas inferências desses mesmos conjuntos de dados.

Na medicina, o impacto da inteligência artificial pode verificar-se em três níveis: para os profissionais de saúde, predominantemente por potenciar uma interpretação de imagens mais rápida e precisa; para o sistema de saúde, melhorando o fluxo de trabalho e reduzir o erro médico; e para o paciente, permitindo-lhes o processamento da sua própria informação para promover saúde. Apesar das suas aplicações nas mais diversas especialidades da medicina, uma área que tem o potencial para ser revolucionada pelo uso desta tecnologia é a saúde mental. À medida que as técnicas de inteligência artificial continuam a ser trabalhadas e melhoradas, poderá ser possível definir as doenças mentais mais objetivamente do que o atual esquema de classificação do DSM-5, identificá-las mais precocemente ou num estágio pródromo quando as intervenções possam ser mais eficazes e dirigir os tratamentos baseando-se nas características únicas do indivíduo.

A essência da medicina baseada na evidência (MBE) é tomar decisões clínicas informadas com base na compreensão de informação do passado. Ou seja, a base da BEM é estabelecer correlações clínicas

através de associações e padrões em bases de dados de informações existentes. Tradicionalmente, métodos estatísticos abordavam esta tarefa caracterizando os padrões da informação como equações matemáticas.¹

A medicina moderna enfrenta o desafio de adquirir, analisar e aplicar uma quantidade imensa de conhecimentos para resolver problemas clínicos complexos.² Além disso, a produção de quantidades massivas de dados como imagens de exames médicos de alta resolução, biossensores com monitorização contínua, sequenciamento do genoma e registos médicos eletrônicos, faz com que os limites humanos para a análise de tal informação sejam facilmente ultrapassados levando a uma dependência cada vez maior das máquinas.³

A quantidade de informação relacionada com os cuidados de saúde cresceu: hospitais típicos com 500 camas têm aproximadamente 50 petas bytes de informação. A quantidade total de dados digitais com os cuidados de saúde é estimada em 153 exabytes e é expectado que em 2020 chegue aos 2314 exabytes.⁴

1.2 INTELIGÊNCIA ARTIFICIAL NA MEDICINA

A inteligência artificial (IA) é, de uma forma muito simplista, a capacidade de fazer com que uma máquina consiga imitar um comportamento inteligente humano. As técnicas de IA e de aprendizagem de máquina (ML, do inglês *machine learning*) têm o potencial de transformar os cuidados de saúde ajudando a processar as grandes quantidades de informação produzida no dia-a-dia da atividade médica e retirando novas inferências desses mesmos conjuntos de dados.

Enquanto o conhecimento humano é limitado pela capacidade de aprendizagem, acesso às bases de conhecimento e experiência própria, máquinas dotadas de IA podem rapidamente sintetizar infor-

mação de um número ilimitado de fontes de informação médica. Para otimizar o potencial da IA, o ideal são grandes bases de dados (como por exemplo os registos médicos eletrônicos realizados todos os dias por milhares de médicos) que possam ser analisadas computacionalmente, relevando tendências e associações que, caso contrário, seriam difíceis de extrair para o ser humano⁵. Além disso, as máquinas conseguem detectar padrões não decifráveis pelos métodos tradicionais de bioestatística através do processamento de grandes quantidades de conjuntos de dados através de modelos matemáticos organizados em camada.⁶ Basicamente, a sustentação da IA é a recolha de uma quantidade significativa de bancos de dados e transformá-los para ganhar experiência e conhecimento.

Um dos grandes benefícios da IA/ML reside na sua habilidade para aprender através de experiências/*feedback* do mundo real (treino) e a sua capacidade de melhorar o seu desempenho (adaptação).⁷ Estes sistemas são passíveis de uma aprendizagem com cada caso e podem ser expostos, em minutos, a mais casos do que um clínico seria exposto em muitas vidas.⁸

Segundo a literatura, a IA está a ser aplicada no sector médico em pelo menos 4 categorias distintas: 1. avaliar o risco de início de doença e em estimar o sucesso terapêutico antes de o iniciar; 2. gerir ou avaliar complicações; 3. assistência em cuidados do doente quer seja em fase ativa do tratamento ou em processo de tratamento; 4. investigação destinada à elucidação de mecanismos patológicos e/ou tratamentos ideais para uma doença (Figura 1).⁹ A inteligência artificial no mundo da medicina é um tópico em crescimento nos últimos anos que parece não abrandar. A investigação e, conseqüentemente, a quantidade de publicações em IA tem aumentado exponencialmente.

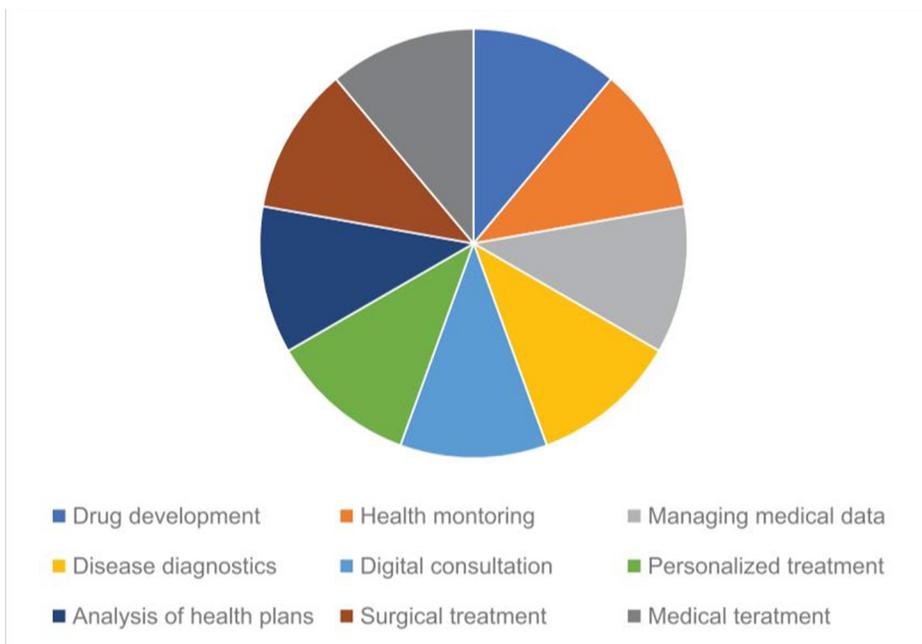


Figura 1. Aplicações mais comuns da IA na medicina

Em 2016, projetos de IA relacionados com os cuidados de saúde atraíram mais investimento do que projetos em qualquer outro sector da economia global.⁸

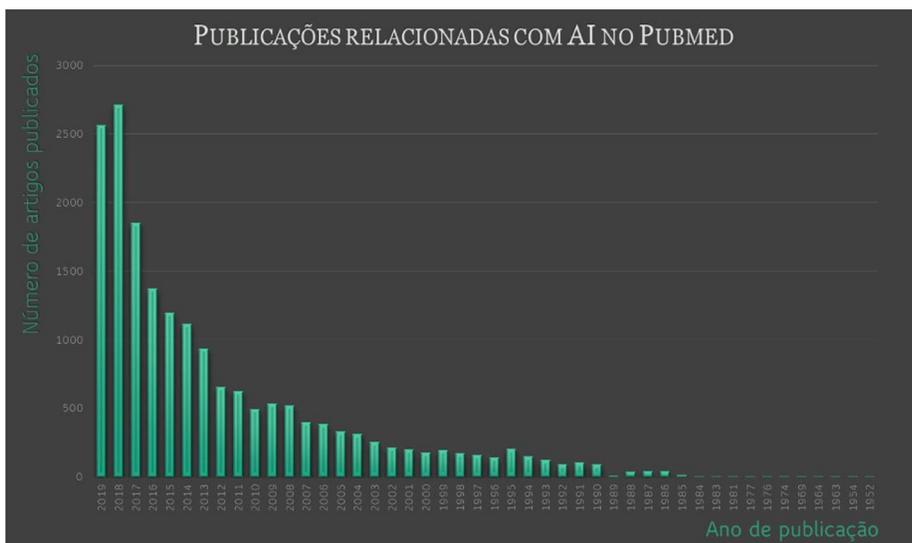


Figura 2. Número de artigos publicados no PubMed por ano com palavras chave “inteligência artificial” + “medicina”

As inúmeras aplicações deste ramo da ciência da computação e a atualidade do tema fazem com que seja impossível uma pessoa ficar indiferente à sua presença.

Este livro irá começar com uma breve explicação de alguns conceitos que considero importantes para uma compreensão mais profunda sobre esta tecnologia. O seguinte capítulo será sobre algumas aplicações em várias especialidades para demonstrar o quão abrangente pode ser. Pelo meu especial interesse e pelo seu potencial para revolucionar a área respectiva à saúde mental, um capítulo será dedicado à sua exploração. O trabalho acaba com uma análise sobre possíveis limitações na aplicação desta tecnologia assim como alguns desafios para o futuro.

1.3 CONCEITOS FUNDAMENTAIS

Ao aplicar tecnologia dotada de IA aos pacientes, os médicos não são os que se encontram no banco de trás, mas sim aqueles que se encontram no lugar do condutor uma vez que têm de ser capazes de resolver qualquer ansiedade, confusão e questões que o paciente ou o público possa ter sobre as aplicações de IA na medicina. Assim, os profissionais de saúde são responsáveis por assegurar que IA se torne numa tecnologia que beneficie o cuidado do doente. Por estas razões, é crucial que adquiram conhecimentos sólidos e experiência nesta área.¹⁰

Embora IA seja um termo geral que contenha muitas formas de ciência da computação, na medicina podemos focar-nos maioritariamente nos seguintes termos¹¹:

1.3.1 Processamento digital de imagem

Muitas das técnicas de processamento digital de imagens foram desenvolvidas nos anos de 1960 no Jet Propulsion Laboratory, MIT, Bell Labs, University of Maryland, e alguns outros lugares, com aplicação para imagens de satélite, conversão de padrões de wirephoto, imagens médicas, vídeofone, reconhecimento de caracteres e aprimoramento de foto. Mas o custo de processamento foi muito alto com o equipamento computacional da época. Nos anos de 1970, o processamento digital de imagem se proliferou, quando computadores mais baratos e hardwares dedicados foram disponibilizados.

O processamento digital de imagem é um processo matemático que realça uma imagem para melhorar a clareza, retirar informações específicas ou para medição de padrões. Basicamente o input é uma imagem e o output é uma imagem mais bem definida para um propósito específico.

1.3.2 Visão computacional

Visão computacional (CV - Computer Vision) é o processamento de uma imagem para permitir a sua identificação e fornecer um output apropriado, ou seja, a interpretação dessa imagem.

Visão computacional é a ciência e tecnologia das máquinas que enxergam. Ela desenvolve teoria e tecnologia para a construção de sistemas artificiais que obtêm informação de imagens ou quaisquer dados multidimensionais. Exemplos de aplicações incluem o controle de processos (como robôs industriais ou veículos autônomos), detecção de eventos, organização de informação, modelagem de objetos ou ambientes e interação (atrelado a interação humano-computador).

A visão computacional também pode ser descrita como um complemento da visão biológica. Na visão biológica, a percepção visual dos humanos e outros animais é estudada, resultando em modelos em como tais sistemas operam em termos de processos fisiológicos. Por outro lado, a visão computacional estuda e descreve sistemas de visão artificial implementados por hardware ou software.

Sub campos de pesquisa incluem reconstrução de cena, detecção de eventos, reconhecimento de objetos, aprendizagem de máquina e restauração de imagens.

1.3.3 Redes neurais

Em ciência da computação e campos relacionados, redes neurais artificiais (RNAs) são modelos computacionais inspirados pelo sistema nervoso central de um animal (em particular o cérebro) que são capazes de realizar o aprendizado de máquina bem como o reconhecimento de padrões. Redes neurais artificiais geralmente são apresentadas como sistemas de “neurônios interconectados, que podem computar valores de entradas”, simulando o comportamento de redes neurais biológicas.

As redes neurais são ferramentas analíticas computacionais inspiradas no sistema nervoso e na sua habilidade em aprender padrões complicados mudando a força das conexões sinápticas entre neurónios.¹² Nas redes neurais artificiais (ANN, do inglês *artificial neural networks*), o *input* é inserido numa série de algoritmos e o *output* desses algoritmos é reinserido noutro conjunto diferente de algoritmos de maneira a chegar ao *output* final. Uma rede neural profunda (DNN, do inglês *deep neural network*) é quando existe mais do que uma camada “escondida” entre o *input* e o *output* e uma rede neural convolucional (CNN, do inglês *convolutional neural network*) é um outro

tipo específico de ANN, tipicamente baseada em algoritmos de aprendizagem profunda com diversas camadas escondidas para analisar a informação relacionada especificamente com a CV (Figura 3).

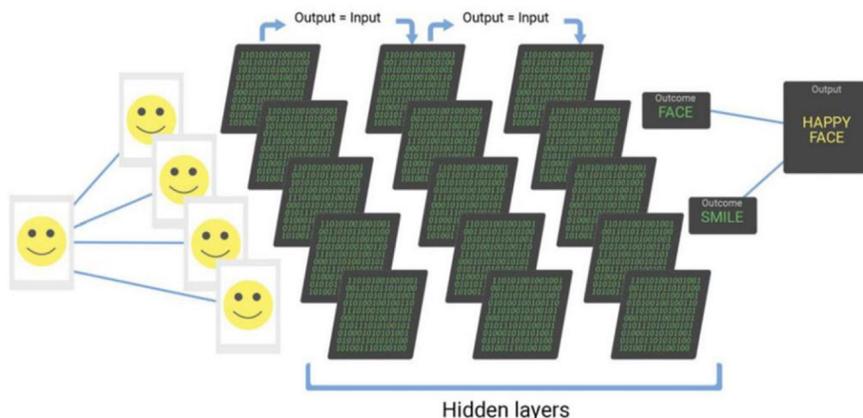


Figura 3. Uma imagem como input de uma CNN.¹¹

1.3.4 Aprendizagem de máquina

Aprendizagem de máquina (do inglês *machine learning* – ML) é um termo refere-se à capacidade de um computador aprender por experiência, isto é, modificar à sua maneira de processar baseando-se em informações recém-adquiridas. Aprendizagem de máquina é um subcampo da Engenharia e da ciência da computação que evoluiu do estudo de reconhecimento de padrões e da teoria do aprendizado computacional em inteligência artificial[1]. Em 1959, Arthur Samuel definiu aprendizado de máquina como o “campo de estudo que dá aos computadores a habilidade de aprender sem serem explicitamente programados. O aprendizado automático explora o estudo e construção de algoritmos que podem aprender de seus erros e fazer previsões sobre dados. Tais algoritmos operam construindo um modelo a partir de inputs amostrais a fim de fazer previsões ou decisões guiadas pelos dados ao invés de simplesmente seguindo inflexíveis e estáticas ins-

truções programadas. Enquanto que na inteligência artificial existem dois tipos de raciocínio (o indutivo, que extrai regras e padrões de grandes conjuntos de dados, e o dedutivo), o aprendizado de máquina só se preocupa com o indutivo.

1.3.4 Aprendizagem profunda

A aprendizagem profunda (do inglês *deep learning* - DL) (também conhecida como aprendizado estruturado profundo, aprendizado hierárquico ou aprendizado de máquina profundo) é um ramo de aprendizado de máquina (Machine Learning) baseado em um conjunto de algoritmos que tentam modelar abstrações de alto nível de dados usando um grafo profundo com várias camadas de processamento, compostas de várias transformações lineares e não lineares.

A aprendizagem profunda é parte de uma família mais abrangente de métodos de aprendizado de máquina baseados na aprendizagem de representações de dados. Uma observação (por exemplo, uma imagem), pode ser representada de várias maneiras, tais como um vetor de valores de intensidade por pixel, ou de uma forma mais abstrata como um conjunto de arestas, regiões com um formato particular, etc. Algumas representações são melhores do que outras para simplificar a tarefa de aprendizagem (por exemplo, reconhecimento facial ou reconhecimento de expressões faciais). Uma das promessas da aprendizagem profunda é a substituição de características feitas manualmente por algoritmos eficientes para a aprendizagem de características supervisionada ou semi-supervisionada e extração hierárquica de características.

A pesquisa nesta área tenta fazer representações melhores e criar modelos para aprender essas representações a partir de dados não rotulados em grande escala. Algumas das representações são ins-

piradas pelos avanços da neurociência e são vagamente baseadas na interpretação do processamento de informações e padrões de comunicação em um sistema nervoso, tais como codificação neural que tenta definir uma relação entre vários estímulos e as respostas neuronais associados no cérebro.

Várias arquiteturas de aprendizagem profunda, tais como redes neurais profundas, redes neurais profundas convolucionais, redes de crenças profundas e redes neurais recorrentes têm sido aplicadas em áreas como visão computacional, reconhecimento automático de fala, processamento de linguagem natural, reconhecimento de áudio e bioinformática, onde elas têm se mostrado capazes de produzir resultados do estado-da-arte em várias tarefas.

É um subtipo de aprendizagem de máquina que usa redes neurais profundas com múltiplas camadas intermédias de neurónios artificiais entre o *input* e o *output* e como o córtex visual, estes neurónios aprendem a hierarquia de características progressivamente mais complexas.¹² A aprendizagem profunda provocou atração intuitiva pela área da saúde e possíveis aplicações dado à sua robustez no reconhecimento de padrões complexos e construção de modelos preditivos a partir de grandes conjuntos de informação.¹³

1.3.5 Processamento de linguagem natural

Processamento de linguagem natural (NLP, do inglês *neural language processing*) é um subtipo de AI que envolve os métodos algorítmicos supramencionados. Refere-se à maneira como os computadores processam e analisam a linguagem humana que se encontram em textos não estruturados e requer traduções, entendimento semântico e extração de informação¹⁴. Processamento de língua natural (PLN) é uma subárea da ciência da computação, inteligência artificial e da

linguística que estuda os problemas da geração e compreensão automática de línguas humanas naturais. Sistemas de geração de língua natural convertem informação de bancos de dados de computadores em linguagem compreensível ao ser humano e sistemas de compreensão de língua natural convertem ocorrências de linguagem humana em representações mais formais, mais facilmente manipuláveis por programas de computador. Alguns desafios do PLN são compreensão de língua natural, fazer com que computadores extraiam sentido de linguagem humana ou natural e geração de língua natural.

CAPÍTULO 2

INTELIGÊNCIA ARTIFICIAL NA MEDICINA

2.1 OS BENEFÍCIOS DO USO DA INTELIGÊNCIA ARTIFICIAL NA MEDICINA

Na medicina, o impacto da IA pode verificar-se em três níveis: para os profissionais de saúde, predominantemente por potencializar uma interpretação de imagens mais rápida e precisa; para o sistema de saúde, melhorando o fluxo de trabalho e reduzir o erro médico; e para o paciente, permitindo-lhes o processamento da sua própria informação para promover saúde.³

Desta forma, no futuro, quase todos os clínicos nas mais diversas especialidades vão usar este tipo de tecnologia, em particular aprendizagem profunda uma vez que esta capacidade de reconhecimento de padrões através de redes neurais profundas pode ajudar a interpretar exames médicos, imagens de anatomia patológica, lesões da pele, imagens da retina, eletrocardiogramas, endoscopias, faces, sinais vitais entre outros.

Uma especialidade que tem particularmente evoluído com a ajuda de IA é a radiologia, isto porque esta tecnologia ajuda maioritariamente com as tarefas de reconhecimento de imagem através de técnicas de processamento de imagem e visão computacional para que o diagnóstico seja mais rápido, a visualização de patologias seja mais clara, situações de emergência sejam alertadas e a falta de mão-de-obra crítica seja colmatada¹¹. Assim, DNN já foram aplicadas numa série de exames médicos como: radiografias ósseas para avaliação de fraturas e idade óssea¹⁵; tomografia computadorizada (TC) para avaliação de fraturas compressivas vertebrais¹⁶ ou massas hepáticas¹⁷; TC crânio-encefálica (TC-CE) para avaliação de hemorragia¹⁸ ou traumatismo craniano¹⁹; ecocardiogramas²⁰ e mamografias²¹.

Apesar da heterogeneidade de opiniões dos patologistas nas interpretações das imagens de anatomia patológica, a aprendizagem

profunda da digitalização destes slides oferece o potencial de aumentar a exatidão e a velocidade de interpretação dos mesmos.³ Um estudo realizado por *Steiner DF et al.* demonstrou que a sinergia combinada entre os patologistas e o algoritmo para a interpretação de slides histopatológicos de nódulos linfáticos levava a uma maior exatidão.²²

Outras especialidades como oftalmologia e gastroenterologia também se beneficiaram da visão computacional enquanto subtipo de inteligência artificial na medida em que foram realizados estudos que demonstraram a sua utilização quer em interpretação de de imagens do fundo ou de tomografia de coerência ótica (OCT, do inglês *optical coherence tomography*) para o diagnóstico de degeneração macular relacionada com a idade²³ ou retinopatias diabéticas²⁴ como também para ajudar os gastroenterologistas a encontrar pólipos adenomatosos diminutos (<5mm) em colonoscopias²⁵.

O potencial uso de fotografias da retina parece ultrapassar o diagnóstico de doenças oculares só por si. Foram colhidas imagens de mais de 280,000 pacientes que foram processadas por uma DNN para avaliar fatores de risco cardiovasculares como idade, sexo, pressão sistólica, se é fumador ou não, hemoglobina A1c e demonstrou-se que o algoritmo conseguia identificar precisamente o sexo a partir da foto da retina. Os restantes fatores mostraram uma AUC de 0,7 o que significa que, com mais investigação, este algoritmo poderá ser útil para uma futura monitorização dos pacientes e dos seus fatores de risco²⁶.

Na dermatologia, a exatidão de diagnóstico de lesões da pele foi comparada entre algoritmos de análise de imagem e dermatologistas e concluindo-se que IA é tão competente quanto especialistas humanos^{27,28}. No que toca à cardiologia, e para além do uso de DNN em ecocardiogramas para diagnosticar doenças como cardiomiopatia hipertrófica, amiloidose cardíaca e hipertensão pulmonar²⁰, também

os eletrocardiogramas têm sido alvo de interpretação por máquinas quer seja para o diagnóstico de enfartes²⁹ ou arritmias³⁰.

Para o sistema de saúde, a grande ajuda é baseia-se nas ferramentas preditivas de inteligência artificial que podem estimar o risco de readmissão do paciente no hospital, o risco de sépsis ou que pacientes beneficiariam de cuidados paliativos. Isto poderá ser feito com base no tratamento da informação presente nos registos médicos eletrónicos. O processamento de linguagem natural pode ser crucial nesta área, mas também é capaz de ser útil numa tentativa de substituir os teclados e a escrita humana nas visitas médicas.

Estas tecnologias permitem ao público ter um papel mais ativo na sua saúde. Vários *wearables* estão disponíveis como por exemplo um algoritmo para a deteção de fibrilação auricular pelos *smart watches*, aplicações que determinam a aderência à terapêutica (AiCure), etc. No entanto, apesar de todos estes benefícios há que ter em conta algumas das limitações da IA nomeadamente aquelas que se transformam em erros decorrentes de transformações matemáticas complexas efetuadas sobre os dados pelos sistemas computacionais e que exigirão vigilância extra para os detectar. Estes erros e vieses enigmáticos podem sistematicamente prejudicar numerosos doentes ao mesmo tempo e com isso, piorar as disparidades de saúde em grande escala. Além disso, mesmo uma aplicação robusta de IA pode reduzir a eficiência clínica e causar erros médicos adicionais, se não estiver adequadamente integrada no fluxo atual do trabalho clínico. De facto, um fluxo de trabalho melhor e mais organizado permitiria que médicos e aplicações com IA compensassem as suas diferentes e complementares deficiências de forma a aumentarem a segurança do doente e a eficiência clínica. Igualmente, e tendo em conta a esperança que se tem hoje em dia nas aplicações emergentes de IA na Medicina, é necessário reconhecer a fragilidade destes sistemas, a importância de definir as

estruturas corretas para a sua utilização e a necessidade de garantir um rigoroso controlo de qualidade, incluindo a supervisão humana, para evitar que se caminhe na direção de resultados inesperados, indesejados e prejudiciais.

2.2 DISCUSSÃO ÉTICA SOBRE O USO DE IA NA MEDICINA

Do ponto de vista ético, a discussão ética da utilidade e uso de IA deixam-se aqui algumas considerações sobre esta relação entre ética e IA. De facto, há muita esperança e entusiasmo em torno do uso da IA na área da saúde devido aos seus potenciais benefícios, ou seja, o potencial de tornar os cuidados de saúde mais eficientes, de acelerar e reduzir erros no diagnóstico, de ajudar os pacientes a gerir a sua própria doença e de contribuir para a diminuição do preconceito e erro humano. No entanto, há algumas questões importantes a serem consideradas: quem responsável pelas decisões tomadas pelos sistemas de IA? Qual o potencial da IA para tomar decisões erradas, como validar os resultados da aplicação de IA? O uso crescente da IA levará a uma perda de contato humano nos cuidados? O que acontece se os sistemas de IA forem invadidos, ou seja, como se garante a segurança e a privacidade de dados potencialmente sensíveis? Como garantir a confiança do público no desenvolvimento e uso da tecnologia associada a IA? Quais os efeitos da IA no sentido de dignidade e isolamento social das pessoas em situações de cuidado? Qual o papel e as competências exigidas aos médicos e como isso impacta a relação médico doente e o exercício profissional? Qual o potencial da IA para ser usada para fins maliciosos?

2.3 DESAFIOS PARA INTELIGÊNCIA ARTIFICIAL NA SAÚDE

A implementação das tecnologias de IA pode apresentar desafios consideráveis para governos e organizações, na medida em que o escopo e a profundidade do potencial de aplicação aumentam e o uso de IA torna-se *mainstream*¹¹¹.

Os desafios são diversos, dentre eles: sociais, económicos, organizacionais/gerenciais, tecnológicos/implementação tecnológica, políticos/legais/diplomáticos, éticos e, também, relacionados com a base de dados ^{xiv} 111.

Visto que os desafios são variados e muitos, esta secção destaca os seguintes pontos: interação homem-máquina; confiança na IA; aceitação/capacitação de profissionais e utentes; investimento/manutenção dos aparelhos baseados em IA e a segurança e confidencialidade dos dados de saúde.

O desafio mais proeminente para a IA na saúde é a interação homem-máquina, pois faz-se necessário, entre outros, acoplar aspetos da sensibilidade humana à artificialidade de uma máquina, além de perceber e interpretar *inputs* de situações bastante variadas¹¹². A tecnologia deve servir para ajudar o ser humano nas tarefas rotineiras e naquelas que lhe retiram tempo para trabalhos de maior complexidade¹¹³. O ser humano precisa de aprender a trabalhar sinergeticamente com as máquinas

A confiança plena nos resultados produzidos pela IA é um outro grande desafio a ser enfrentado, por exemplo ao nível da validação, da aceitação ou da adopção da inovação pelos profissionais de saúde. São necessárias provas de evidência e validação robusta dos algoritmos de IA para fins médicos, para que seja possível produzir resultados confiáveis e implementáveis na prática clínica⁷⁶. Portanto,

são pré-requisitos para a melhor incorporação da IA na prestação de cuidados de saúde, que a mesma seja precedida de estudos científicos rigorosos, cujos resultados sejam publicados em revistas com revisão por pares e que estes sejam, posteriormente, validados no dia a dia clínico⁷⁶.

2.4 BARREIRAS PARA O USO DE IA NA MEDICINA

Um estudo realizado na China com *stakeholders* do setor público da saúde concluiu que a maior parte dos desafios se encontra nas questões políticas, sociais, legais e questões sobre base de dados¹⁴³.

Quanto à aceitação das inovações, paira uma incerteza decorrente da complexidade derivada da entrada dessas novas tecnologias e como devem ser utilizadas para promoverem proximidade, aumentarem o tempo com os doentes e melhorarem a qualidade dos cuidados¹¹³. Para que esses objetivos sejam atingidos, faz-se necessário uma boa gestão dos desafios inerentes à interação homem-máquina, confiança em relação à IA e sua aceitação.

Como forma de mitigar a natural apreensão associada à IA, é de extrema importância atentar para a capacitação dos profissionais de saúde e dos utentes em relação às novas tecnologias¹¹⁴. Introduzi-las através de um investimento a longo prazo e uma liderança eficiente e digitalmente capaz, de modo a criar um ambiente de aprendizagem tecnológica contínua e instalar uma cultura de inovação, priorizando sempre as pessoas⁷⁵. O mesmo deve se aplicar aos estudantes durante sua formação médica¹¹⁵.

Os prestadores de cuidados de saúde de todo o mundo depararam-se com um desafio único: a necessidade de melhorar os resultados de saúde dos utentes ao mesmo tempo em que é necessário conter custos¹¹⁶. A necessidade de investimentos em recursos materiais

e humanos para incorporação da IA na área de saúde, bem como a sua respetiva manutenção, constituem um desafio importante, pois é preciso manter a prestação de cuidados de saúde atualizada em relação às ferramentas de IA e à preparação de profissionais de saúde e utentes, para haver sucesso na utilização das novas tecnologias⁷⁵. Esse, portanto, é um desafio que precisa ser muito bem gerido, para não comprometer a qualidade dos serviços prestados, em geral, e da entrega aos utentes, em particular, dos benefícios proporcionados pelo uso da IA. Adicionalmente, a preocupação relativa à escalabilidade, à integração de dados e sua interoperabilidade, segurança, privacidade e ética dos dados digitais agregados, especialmente para diagnósticos no cenário clínico, são mais exemplos relevantes de desafios a serem enfrentados⁷⁷.

A atenção atualmente dedicada aos dados digitais, permite antecipar que, nos próximos anos, haverá oportunidades de se otimizar a governança dos dados, as preocupações relativas a *cybersecurity*, estruturar acordos éticos e implementar tecnologias digitais e genómicas nas organizações de saúde⁷⁵. O futuro guarda dilemas que requerem o balanço entre os avanços de IA e o direito à privacidade. Este desafio tem sido tratado com mais atenção, uma vez que o direito à reserva da vida privada e o direito ao livre desenvolvimento da personalidade são reconhecidos como direitos fundamentais^{65,117}.

Embora o direito à confidencialidade dos dados de saúde não seja contemplado, à escala global, por uma legislação específica do âmbito da saúde, a União Europeia fez recentes progressos ao criar o Regulamento Geral de Proteção de Dados (GDPR)^{5,118}. As instituições de saúde precisam comunicar com a comunidade científica e agências do governo para colaboração na preservação da privacidade e confidencialidade nos mais diversos domínios da saúde⁶⁵. Além disso, o direito da saúde deve se dedicar para que a privacidade e a confiden-

cialidade sejam resguardados nos futuros cenários da medicina e da genética, em particular no que diz respeito aos desafios criados pela IA¹¹⁷.

Diante do crescimento exponencial do volume de dados de saúde, estes se encontram disponíveis em locais, formas e sistemas distintos, facto que requer uma agregação, ou seja, uma intercomunicação e interoperabilidade para torná-los passíveis de análise por algoritmos de *deep learning*¹¹⁹.

Diferentes estudos têm analisado o potencial e o impacto da IA na área da saúde, na perspectiva da sociedade em geral, da indústria ou mesmo de decisores relevantes^{120,70,75,115}. Contudo, são ainda em número limitado os estudos que se debruçam sobre a opinião dos profissionais de saúde em geral, e dos profissionais médicos em particular, a este respeito¹²¹.

Uma investigação realizada em 2018 em três grandes universidades alemãs com estudantes de medicina permitiu constatar, principalmente, três pontos: os estudantes estão cientes do potencial das aplicações de IA e suas implicações na radiologia e medicina em geral; não temem que um médico radiologista seja substituído por um mecanismo de IA e concordam que a tecnologia deve ser ensinada na formação médica¹¹⁵.

O estudo faz alusão à preocupação inicial dos médicos radiologistas de perderem seus cargos para inovações tecnológicas em um futuro previsível. Em contradição, averiguou-se que os estudantes de medicina não temem por essa substituição e mostram-se confiantes na continuação da necessidade de um médico radiologista humano. No entanto, a discussão que veio à tona é a de que a IA não substituirá um médico radiologista, porém este que utiliza a IA poderá substituir os que não a utilizam¹¹⁵.

A radiologia foi uma das primeiras especializações médicas a discutir o impacto da IA e assume a responsabilidade, tanto de ensinar aos estudantes de medicina as tecnologias emergentes nessa área, quanto de alertá-los para desafios específicos que possam surgir¹¹⁵.

Um estudo similar foi realizado no Reino Unido em 2020, com alunos de medicina de 19 universidades diferentes, para investigar suas percepções frente à IA na radiologia, além de examinar o estado da arte da educação em relação à IA¹²².

No geral, os estudantes percebem a importância da IA na saúde e estão dispostos a aceitarem-na em seu meio. Os resultados apontam que metade dos alunos considera-se menos apta a escolher radiologia por conta da IA. Portanto, o treinamento de IA na formação acadêmica precisa ser expandido e aperfeiçoado, para que os alunos se sintam encorajados a realizar a especialização. Os alunos que receberam o treinamento de IA (o qual não estava presente no currículo acadêmico de nenhum participante, ou seja, foram treinamentos efetuados à parte da universidade) se sentem mais confiantes a optarem por radiologia, porém não se sentem preparados para utilizar a tecnologia em sua prática clínica¹²².

A integração da IA na prática de cuidados de saúde e na medicina está ainda no seu início⁷⁶.

CAPÍTULO 3

APLICAÇÕES DE INTELIGÊNCIA ARTIFICIAL NA ÁREA DA SAÚDE

Em 2015, um grupo de investigadores do *Mount Sinai Hospital* de Nova Iorque aplicou um programa de IA sobre a vasta base de dados dos pacientes mantida pelo hospital. Esses dados continham centenas de variáveis relacionadas com os pacientes e extraídas dos resultados de exames por eles realizados, além de visitas médicas, entre outras fontes⁶⁰. O programa de IA, *Deep Patient*, foi treinado através da utilização dos dados de saúde de cerca de 700.000 pacientes e, quando aplicado sobre dados novos, produziu resultados que superaram em muito as expectativas, quanto à predição de doenças⁶¹.

Sem nenhuma instrução especial, o programa descobriu padrões escondidos nos dados e pareceu indicar a propensão dos indivíduos a desenvolver uma gama de doenças, como, por exemplo, o cancro de fígado. Foi capaz de antecipar doenças psiquiátricas, como a esquizofrenia, o que foi uma surpresa para os programadores, uma vez que é sabido que esse distúrbio é de difícil diagnóstico. A investigação foi interrompida, uma vez que os investigadores não compreenderam como o programa estava a acertar e, portanto, não saberiam explicar quando eventualmente errasse⁶¹.

Nos Estados Unidos, o Instituto Nacional de Saúde criou o *All of Us Research Program*⁶² com o intuito de estabelecer um modelo de capacitação dos utentes, ao acelerar a investigação em saúde e avanços médicos, para desenvolverem soluções individualizadas nos cuidados de saúde, incluindo tratamentos e prevenção.

Tal abordagem vai ao encontro do conceito de medicina personalizada, cuja definição é voltada para a gestão da doença, uma vez que considera a variabilidade do indivíduo no ambiente, seu estilo de vida e sua composição genética. Relaciona a individualização dos cuidados de saúde com o impacto futuro da tecnologia digital nos indiví-

duos que assumem um papel mais participativo no que diz respeito à sua própria saúde⁶²⁻⁶⁴.

A IA pode ser aplicada a vários tipos de dados de saúde, estruturados e não estruturados. Os primeiros incluem a técnica do *machine learning*, como por exemplo os sistemas de redes neurais, enquanto os segundos incluem o *deep learning*, constam no processamento de linguagem natural de dados desestruturados⁴.

3.1 APLICAÇÕES DE IA NA MEDICINA

Neste capítulo, alguns exemplos já existentes (não exaustivos) de aplicações de Inteligência Artificial na área da saúde serão apresentados e comentados (Tabela 3), a seguir:

Tabela 3 - Exemplos práticos de aplicação de Inteligência Artificial na saúde

Aplicação de IA	Descrição
Karim	Plataforma artificial de troca de mensagens em árabe para auxiliar pessoas com problemas emocionais advindos da migração forçada. O <i>chatbot</i> utiliza uma linguagem natural para processar o estado emotivo da pessoa e interage com esta através de comentários adequados, recomendações e questões pertinentes ⁶⁷
IA para diagnóstico de cancro de pulmão	A Universidade Americana de Radiologia, em parceria com a Google, realizou um estudo para desenvolver um programa de IA que detectasse o cancro pulmonar ainda em estágio inicial ⁶⁸ O <i>software</i> reduziu em 11% os falsos positivos e em 5% os falsos negativos quando não havia imagem de tomografia computadorizada anterior. Quando havia imagem precedente, o resultado do modelo foi equiparável ao dos médicos ⁶⁸

<p>Primeiro útero virtual a ser construído na Nova Zelândia</p>	<p>Investigadoras da Escola de Medicina da Universidade de Auckland, receberam do governo uma bolsa para um projeto de três anos para criação de um útero virtual. O modelo de computador elaborado tem por objetivo estudar mais detalhadamente o fluxo sanguíneo dentro do órgão, incluindo sua interação com a placenta, além de melhorar a capacidade de detecção precoce em caso de crescimento do próprio⁶⁹</p>
<p>IBM Watson Health</p>	<p>Permite profissionais compartilharem dados de saúde e, com o cruzamento de informações, fornecerem mais conhecimento para os cuidados de saúde via <i>stakeholders</i>. Um ecossistema conectado que atravessa as informações da indústria de saúde, armazenadas em <i>cloud</i> da IBM, e aproveita esse conhecimento para formar um valor compartilhado. A ideia central é combater os desafios de saúde mais urgentes⁷⁰</p>
<p>IBM Watson for Oncology</p>	<p>Solução alimentada por diretrizes relevantes, melhores práticas, periódicos médicos e livros didáticos. Avalia as informações do prontuário de um paciente, as evidências médicas e exibe possíveis opções de tratamento classificadas por nível de confiança O oncologista pode então aplicar seus próprios conhecimentos para identificar as opções de tratamento mais adequadas⁷¹</p>
<p>Watson for Drug Discovery</p>	<p>Permite que investigadores gerem novas hipóteses com a ajuda de visualizações dinâmicas, previsões com base em evidências e processamento de linguagem natural treinados no domínio farmacêutico. É usado por empresas farmacêuticas, de biotecnologia e instituições acadêmicas para ajudar na identificação de novos alvos de medicamentos e de reaproveitamento destes⁷²</p>

CC-Cruiser	<p>Plataforma desenhada, com colaboração de múltiplos hospitais, para auxiliar a gestão da doença e aumentar a qualidade de vida dos utentes com doenças raras. Conecta um sistema de IA diretamente com a entrada de dados de saúde e, também, com possíveis ações clínicas. Com a permissão do utente, seus dados clínicos e pessoais são inseridos no sistema⁹⁰. Este, por sua vez, utiliza os dados para apresentar sugestões clínicas, que são submetidas à crítica dos médicos, com intuito de obter um <i>feedback</i>, o qual é também introduzido no sistema de forma a melhorar sua capacidade de precisão⁴</p>
Tyto Care	<p>A empresa disponibiliza um <i>kit</i>, vinculado a uma aplicação, que permite o próprio consumidor realizar um exame médico em si mesmo, a qualquer momento, e receber diagnóstico, plano de tratamento e prescrição (se for o caso), através do acompanhamento de um médico pela plataforma. Tyto Care se tornou uma solução transformadora para a atenção primária⁷³</p>
Sweetch	<p>Plataforma clinicamente validada, personalizada, adaptativa e baseada em IA para prevenção e tratamento de doenças crônicas e promoção da saúde. Preocupa-se em aumentar a aderência da população nos esforços para prevenir e combater essas doenças, obtendo um maior impacto na saúde pública do que quaisquer melhorias em tratamentos médicos específicos. A aplicação é desenhada para ser funcional no dia a dia das pessoas, ao converter todos os dados a que possui acesso em recomendações personalizadas em momentos oportunos¹⁰⁶</p>

Surgical Theater	Mecanismo digital baseado em IA capaz de simular previamente a cirurgia a ser realizada. Criado por cirurgiões médicos veteranos de guerra da Força Aérea Israelense, é uma inovação virtual trazida para o treinamento cirúrgico. O programa da empresa atualmente é utilizado por diversas instituições médicas importantes, como Mayo Clinic, Mount Sinai, UCLA, dentre outras. Ela permite também que os próprios pacientes tenham conhecimento da anatomia de seu organismo e que médicos residentes possam melhorar suas práticas cirúrgicas, através da realidade virtual formada pelo mecanismo ⁷⁴
DeepMind	Programa da Google responsável por construir sistemas baseados em IA que aprendem a resolver problemas e a desenvolver avanços científicos nas mais variadas áreas, como engenharia, investigação, ética e sociedade, entre outras ⁷⁵

Particularmente na prática clínica, a IA tem encontrado espaço para produzi resultados bastante concretos no apoio à realização de juízos de prognose, diagnósticos e prescrição de tratamentos, no âmbito de diferentes especialidades médicas⁷⁶. Com a sua projetada expansão, um novo paradigma para os cuidados de saúde está a surgir, impulsionado pela geração e disponibilidade crescente de dados de saúde e o rápido progresso de técnicas analíticas para a sua análise e extração de conhecimento^{77,110}.

3.2 REGISTOS MÉDICOS ELETRÓNICOS

Na sua prática clínica, os profissionais de saúde mental têm uma abordagem muito mais centrada no doente do que a maior parte dos outros clínicos, dependem mais das suas habilidades interpessoais

incluindo as relações que estabelecem com os pacientes e a observação direta dos seus comportamentos e emoções. A informação clínica da área da saúde mental é normalmente feita de uma forma subjetiva e qualitativa a partir das afirmações do doente e notas escritas pelo médico⁵. Mesmo assim, a prática clínica na saúde mental tem muito a beneficiar da inteligência artificial, sobretudo do processamento de linguagem natural antes de ser capaz de integrar outros tipos de IA, devido à considerável quantidade de dados em forma de texto (por exemplo: notas clínicas) ou conversas (por exemplo: sessões em consulta).

Tendo isto em conta, já alguns estudos foram feitos neste sentido. Com base nos registos eletrónicos médicos, tentou-se prever casos de depressão⁴⁷, probabilidade de morte por suicídio⁴⁸, detetar ideação ou tentativas suicidas⁴⁹ e identificar sintomas de doença mental severa⁵⁰ (Figura 6).

3.3 OUTRAS APLICAÇÕES

As possibilidades de aplicação da IA têm sido também analisadas noutros aspectos da saúde mental como por exemplo terapias assistidas. Terapia assistida pelo computador (CAT) consiste em programas constituídos por vídeos e questionários entregues ao paciente através de uma plataforma computadorizada para o ajudar a lidar com os seus sintomas. Este tipo de terapia já demonstrou resultados ao reduzir sintomas de depressão e/ou ansiedade⁵¹.

Considerando que a internet está profundamente incorporada no nosso dia-a-dia, terapias eletrónicas (*e-therapies*) poderão ser uma maneira eficaz de proporcionar apoio a indivíduos com patologias da saúde mental. Por exemplo, terapia online moderada (MOST) é uma intervenção baseada na internet que foi especificamente desenhada

para ajudar indivíduos com patologias psiquiátricas, como psicose⁵² e depressão⁵³, através de um sistema de terapia social e online. Esta intervenção consiste num programa que integra apoio de pares online e *networking* social num sítio moderado pelo clínico.

Outros exemplos de aplicação de inteligência artificial em medicina com resultados demonstrados variam desde plataformas de monitorização de terapêutica (AiCure)⁵⁴, identificação de utilizadores das redes sociais com depressão baseando-se nas suas publicações⁵⁵ até à predição de desenvolvimento de psicose em jovens de alto risco através de análise automática de discurso combinada com aprendizagem de máquina⁵⁶.

3.4 ESTUDO DE CASO: INTELIGÊNCIA ARTIFICIAL E SAÚDE MENTAL

A base em que se fundamenta um diagnóstico clínico é uma das grandes diferenças entre o diagnóstico de doenças psiquiátricas e outras doenças médicas. Ao contrário das doenças físicas que são baseadas em patologia biológica mensurável, as doenças psiquiátricas ainda são muito dependentes da definição operacional e subjetiva do diagnóstico. Desde há muito que a psicopatologia e a abordagem fenomenológica são uma parte importante da psiquiatria³¹ porque o diagnóstico e avaliação de patologias psiquiátricas é primariamente baseado nas expressões dos próprios pacientes, comportamentos relatados pelos cuidadores e avaliação do psiquiatra.³²

À medida que as técnicas de inteligência artificial continuam a ser trabalhadas e melhoradas (Figura 4), poderá ser possível definir as doenças mentais mais objetivamente do que o atual esquema de classificação do *Diagnostic and Statistical Manual of Mental Disorders, Fifth edition* (DSM-5), identificá-las mais precocemente ou num estágio

pródromo quando as intervenções podem ser mais eficazes, e dirigir os tratamentos baseando-se nas características únicas do indivíduo.

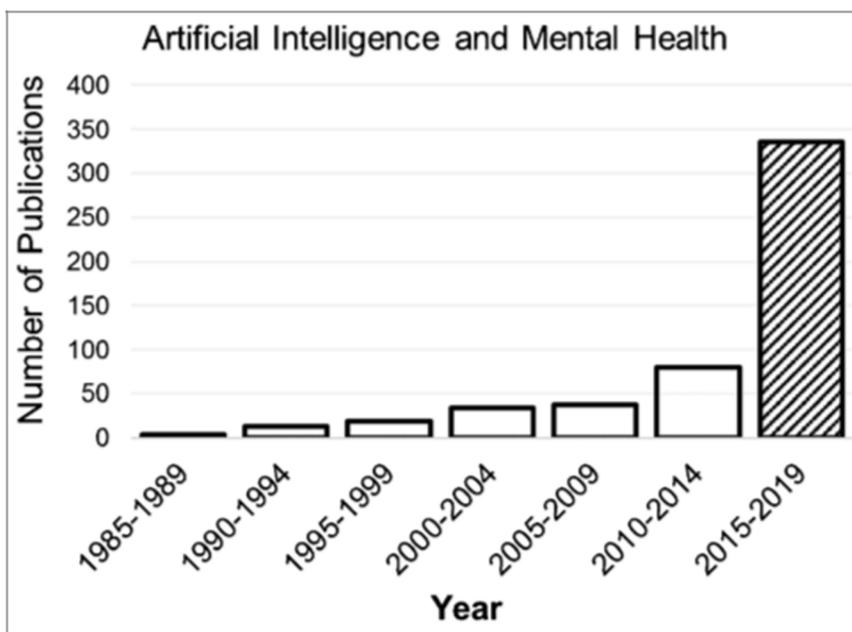


Figura 4. Crescimento exponencial de artigos publicados sobre a associação de AI e saúde mental.⁵

3.4.1 NEUROMARCADOR ES EM PSIQUIATRIA

Um biomarcador é uma característica biológica medida objetivamente e avaliada enquanto indicador de processos normais ou patológicos ou indicador de resposta à terapêutica ou não. Pode ser identificado a nível molecular, celular, orgânico ou sistêmico. Na definição de biomarcador em psiquiatria, estes “processos” seriam psicopatológicos e o tratamento seria medicação psicotrópica ou psicoterapia.³³ Definir marcadores não é difícil no entanto, validá-los e fazê-los clinicamente úteis é um processo complexo. Um biomarcador é validado quando mostra que a sua relação com um certo propósito clínico é fidedigna, plausível, certa (sensível e específico) e reproduzível em todos os casos clinicamente relevantes. Mesmo assim, quando válidos

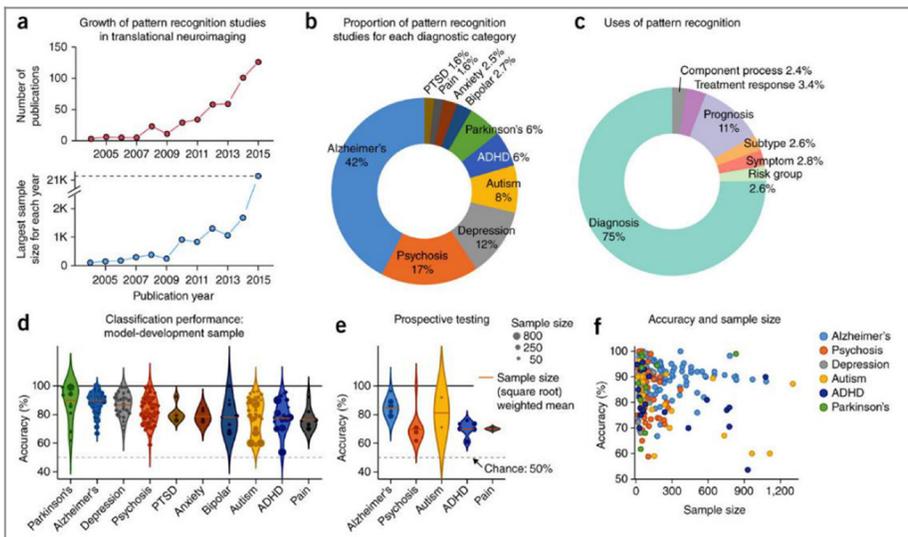
e passíveis de aplicação, os biomarcadores não serão úteis até que se mostre que proporcionam vantagens evidentes quando incorporados nos cuidados clínicos e tomadas de decisão³⁴ (Figura 5).

Embora numerosos marcadores neurobiológicos de patologias psiquiátricas tenham sido já estudados e identificados, a maior parte destes achados não foram ainda incluídos nos critérios diagnósticos. O único marcador diagnóstico biológico presente no DSM-5 é deficiência de hipocretina na narcolepsia³⁵.

É emergente uma nova maneira de pensar sobre a neuroimagem que resulta da integração de ideias de aprendizagem de máquina, *big data*, investigação reproduzível e uma ciência aberta com objetivos translacionais ao alcance de todos: *predictive*

*modelling*³⁶. Esta abordagem utiliza técnicas de reconhecimento de padrões no sentido de desenvolver modelos integrados da atividade através de múltiplas regiões cerebrais para prever resultados clínicos.

Figura 5. Informações estatísticas sobre estudos feitos na área dos neuromarcadores.³⁶



Também este modelo preditivo, com a ajuda da aprendizagem de máquina, tem crescido ao longo das últimas décadas na neuroimagem translacional, com mais de 500 artigos publicados. Estes estudos são mais prevalentes na doença de Alzheimer e demências relacionadas, mas também têm sido alargados a outras doenças neurológicas como doença de Parkinson ou doenças da dor e a doenças do foro mental como psicose, depressão, autismo, perturbação da hiperatividade e déficit de atenção, doença bipolar, etc.³⁶

Estes trabalhos foram agrupados em diferentes grupos de acordo com aquilo que procuram: i) estudos diagnósticos, que diferenciam pacientes de controlos saudáveis; ii) estudos de conversão para doença, que tentam prever aqueles que possam, mais tarde, evoluir e/ou detetar doentes em estádios iniciais; e iii) estudos de predição de resposta ao tratamento.

i) Estudos de diagnóstico

Este tipo de modelos pode fornecer informação importante sobre relações entre doenças e sintomas a um nível biológico, ajudar a identificar subgrupos ou subtipos que não estão expressos nas atuais categorias diagnósticas, mas que podem potencialmente ser informativos sobre a escolha terapêutica.

Como muitas perturbações psiquiátricas e patologias neurológicas são comórbidas, o diagnóstico baseado em imagens cerebrais pode ajudar a identificar características distintivas da neuropatologia e fornecer novas

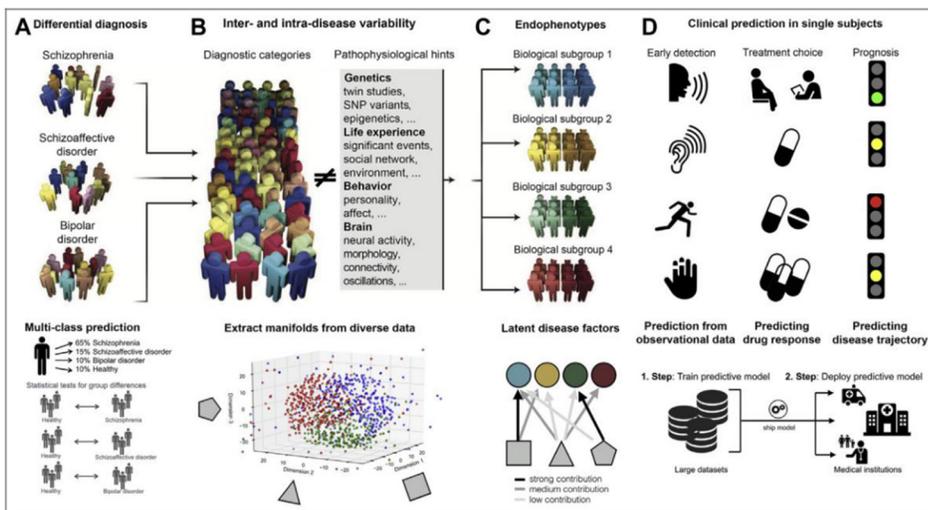
maneiras de examinar a sobreposição entre os distúrbios³⁶. Um estudo utilizou informação de FDG-PET para diferenciar pacientes com doença de Parkinson idiopática, atrofia multissistémica e paralisia supranuclear progressiva. Enquanto especialistas em patologias do movimento chegaram ao diagnóstico final após dois anos

de acompanhamento clínico, classificações baseadas nestas imagens atingiram uma precisão elevada (91%-98% PPV)³⁷.

Um outro estudo foi feito usando ressonância magnética funcional (fMRI) numa grande amostra de pacientes com depressão e demonstrou que os mesmos podem ser subdivididos em quatro subtipos neurofisiológicos ('biótipos') definidos por padrões distintos de disfunção das conexões entre redes límbicas e frontostriatais³⁸. O agrupamento destes pacientes permitiu o desenvolvimento de biomarcadores com alta sensibilidade e especificidade (82-93%) para subtipos de depressão. Esses biótipos não poderiam ser diferenciados apenas com base nas características clínicas, mas estão associados a diferentes perfis de sintomas clínicos. Foi possível, também graças a estas imagens, prever a capacidade de resposta a terapia de estimulação magnética transcraniana.

Um tipo específico de aprendizagem profunda - aprendizagem não supervisionada - pode ser útil para esta organização de patologias em subtipos. Por ser um método que requer grandes quantidades de dados preferencialmente com múltiplos diagnósticos, existem poucos estudos sobre o mesmo. Um estudo agrupou pacientes com psicose - e incluiu participantes com esquizofrenia, perturbação esquizoafetiva e bipolaridade - em três biótipos transdiagnósticos baseando-se em informação de eletroencefalogramas (EEG) e neuropsicologia³⁹. Outro grupo usou ressonância magnética nuclear funcional (fMRI) e agrupou 458 doentes em quatro biótipos de depressão que respondiam diferentemente a estimulação transcraniana magnética⁴⁰.

Figura 6. Desafios atuais para medicina de precisão em psiquiatria e possíveis soluções através de aprendizagem de máquina.⁴¹



ii) Estudos de conversão para doença

Este tipo de estudos tem sido mais ativo e bem-sucedido na doença de Alzheimer (AD) principalmente porque a neuroimagem na AD tem recolhido informação longitudinal de pacientes com compromisso cognitivo leve (MCI), que é um estado translacional entre AD e envelhecimento normal. Um estudo combinou informação de MRI estrutural e PET conseguiu prever a conversão de MCI para AD com uma precisão de 83,3%⁴².

Outro modelo promissor é o *Spatial Pattern of Abnormality for Recognition of Early Alzheimer's Disease (SPARE-AD) index*. É um classificador de padrões, baseado nos padrões espaciais de atrofia cerebral medidos por MRI estrutural e que indica a presença de padrão de atrofia cerebral característica de AD⁴³. Scores SPARE-AD predizem, subsequentemente, declínio cognitivo e transição para AD⁴⁴.

Também já foram desenvolvidos alguns modelos preditivos noutras perturbações como psicose e depressão embora não tenham sido validados.

iii) Estudos de predição de resposta ao tratamento

Em várias patologias psiquiátricas e neurológicas, uma melhor compreensão sobre a razão pela qual alguns pacientes respondem a certos tratamentos enquanto outros não, pode ajudar os clínicos a tomar decisões mais eficazes e melhorar os *outcomes* clínicos a longo prazo⁴⁵.

Um estudo conseguiu discriminar em pacientes com perturbação do pânico, os que responderiam a terapia comportamental cognitiva e os que não baseando-se em fMRI que documentavam as respostas durante o condicionamento do medo⁴⁶.

CAPÍTULO 4

CONCLUSÃO

A aplicação da inteligência artificial na medicina pode estar apenas no seu início e não há como negar que é uma área muito promissora, no entanto, ainda é relativamente fraca em dados e provas.

Não pode haver exceções para a inteligência artificial na medicina. Requer estudos rigorosos, publicações dos resultados em revistas revisadas por pares e validação clínica no mundo real antes de ser implementado nos cuidados com pacientes.

Outro ponto importante a realçar é o problema da caixa preta da IA que se refere ausência de clareza e transparência acerca da forma como estes algoritmos chegam às suas conclusões, aspeto é atribuído ao elevado número das variáveis e das estruturas subjacentes complexas que a aprendizagem profunda requer⁵⁷. Muitos acreditam que construir modelos de aprendizagem profunda para tarefas clínicas facilmente interpretáveis pode ajudar a acelerar a implementação destes modelos. Se os clínicos conseguirem entender o porquê de um modelo estar a predizer um certo diagnóstico ou prognóstico, serão muito mais propensos a usá-los em pacientes. Não é que os médicos tenham uma preferência por algo que estimule a necessidade de uma explicação, mas sim porque têm uma obrigação ética e epistêmica de fazê-lo da melhor maneira possível⁵⁸. Para este tipo de decisões, são sempre necessárias razões e um agente humano que assuma responsabilidade.

Por outro lado, o grande obstáculo de uma tecnologia bem-sucedida é a falta de um entendimento geral sobre a mesma entre os utilizadores. Com o conhecimento de que estatutos socioeconómicos baixos são um facto de risco major para a mortalidade prematura, o uso desproporcionado de AI naqueles que “podem” comparando com aqueles que “não-podem”, tem o potencial para ampliar esta, já existente, lacuna nos *outcomes* de saúde.

Para além disso, o sucesso da inteligência artificial depende dos dados que usa. Assim, a FDA⁷ apresenta algumas condições para que a aprendizagem de máquina ou profunda leve à criação de programas que sejam de qualidade sendo necessário que os dados usados seja relevante para o problema clínico e para o paradigma clínico actual.

Deve também haver uma separação entre os conjuntos de treino, de sintonização e de teste bem como um nível de transparência do *output* e do algoritmo para os utilizadores.

Como já referido anteriormente, a tecnologia IA oferece extensos benefícios para além de melhorar a deteção e diagnóstico de doenças mentais. Os algoritmos podem ser utilizados para tirar conclusões de grandes e variadas fontes de dados e levar a uma melhor compreensão sobre a prevalência de doenças mentais a nível populacional, descobrir mecanismos biológicos de doença, fatores de risco ou de proteção, oferecer tecnologia para monitorizar o curso do tratamento e/ou adesão à medicação, transmitir sessões terapêuticas remotas ou auto-avaliações inteligentes. Mais importante será permitir que os profissionais de saúde mental se concentrem nos aspetos humanos da medicina que só podem ser alcançados através da relação médico-paciente.

Chen and Asch⁵⁹ sugeriram que a aprendizagem de máquina é capaz de ter atingido o seu pico de expectativas na medicina. Isto, contudo, poderá ser considerado um ponto positivo, visto que permite um olhar mais sóbrio sobre como a aprendizagem de máquina ou a inteligência artificial podem ser aplicadas de uma maneira significativa onde prevalecem as limitações e os riscos bem como avaliar e discutir os aspectos éticos a ela ligados.

REFERÊNCIAS

Amisha, Paras Malik , Monika Pathania VKR. Overview of artificial intelligence in medicine. *J Fam Med Prim Care*. 2017;6(2):169-170. doi:10.4103/jfmpc.jfmpc

Ramesh AN, Kambhampati C, Monson JRT, Drew PJ. Artificial intelligence in medicine. *Ann R Coll Surg Engl*. 2004;86(5):334-338. doi:10.1308/147870804290

Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. *Nat Med*. 2019;25(1):44-56. doi:10.1038/s41591-018-0300-7

IDC. The digital universe: driving data growth in healthcare. 2014;(0):0. doi:10.20622/jltajournal.21.0_0

Graham S, Depp C, Lee EE, et al. Artificial Intelligence for Mental Health and Mental Illnesses: an Overview. *Curr Psychiatry Rep*. 2019;21(11). doi:10.1007/s11920-019-1094-0

Miller DD, Brown EW. Artificial Intelligence in Medical Practice: The Question to the Answer? *Am J Med*. 2018;131(2):129-133. doi:10.1016/j.amjmed.2017.10.035

US Food and Drug Administration. Artificial Intelligence and Machine Learning in Software as a Medical Device. 2019:1-20. <https://www.fda.gov/downloads/medicaldevices/deviceregulationandguidance/guidancedocuments/ucm514737.pdf>.

Varun HB, Irfan A, Mahiben M. Debate & Analysis Artificial intelligence in medicine: current trends and future possibilities. 2018;(March):2016-2017.

Becker A. Artificial intelligence in medicine: What is it doing for us today? *Heal Policy Technol*. 2019;8(2):198-205. doi:10.1016/j.hlpt.2019.03.004

Park SH, Do KH, Kim S, Park JH, Lim YS. What should medical students know about artificial intelligence in medicine? *J Educ Eval Health Prof.* 2019;16:16-21. doi:10.3352/jeehp.2019.16.18

Mintz Y, Brodie R. Introduction to artificial intelligence in medicine. *Minim Invasive Ther Allied Technol.* 2019;28(2):73-81. doi:10.1080/13645706.2019.1575882

Hinton G. Deep learning—a technology with the potential to transform health care. *JAMA - J Am Med Assoc.* 2018;320(11):1101-1102. doi:10.1001/jama.2018.11100

Naylor CD. On the Prospects for a (Deep) Learning Health Care System. 2018:1- 2doi:10.1001/jama

Hirschberg J MC. NLP Advances in natural Language processing. *Sci Mag.*:2-3. doi:10.1126/science.aaa8685

Dallora AL, Anderberg P, Kvist O, Mendes E, Ruiz SD, Berglund JS. Bone age assessment with various machine learning techniques: A systematic literature review and meta-analysis. *PLoS One.* 2019;14(7):1-22. doi:10.1371/journal.pone.0220242

Bar A, Wolf L, Bergman Amitai O, Toledano E, Elnekave E. Compression fractures detection on CT. *Med Imaging 2017 Comput Diagnosis.* 2017;10134:1013440. doi:10.1117/12.2249635

Yasaka K, Akai H, Abe O, Kiryu S. Deep learning with CNN showed high diagnostic performance in differentiation of liver masses at dynamic CT. *Radiology.* 2018;286(3 – March):887-896.

Arbabshirani MR, Fornwalt BK, Mongelluzzo GJ, et al. Advanced machine learning in action: identification of intracranial hemorrhage on computed tomography scans of the head with clinical workflow integration. *npj Digit Med.* 2018;1(1). doi:10.1038/s41746-017-0015-z

Chilamkurthy S, Ghosh R, Tanamala S, et al. Deep learning algorithms for detection of critical findings in head CT scans: a retrospective study. *Lancet*. 2018;392(10162):2388-2396. doi:10.1016/S0140-6736(18)31645-3

Zhang J, Gajjala S, Agrawal P, et al. Fully automated echocardiogram interpretation in clinical practice: Feasibility and diagnostic accuracy. *Circulation*. 2018;138(16):1623-1635. doi:10.1161/CIRCULATIONAHA.118.034338

Lehman CD, Yala A, Schuster T, et al. Mammographic breast density assessment using deep learning: Clinical implementation. *Radiology*. 2019;290(1):52-58. doi:10.1148/radiol.2018180694

Steiner DF, Macdonald R, Liu Y, et al. Impact of Deep Learning Assistance on the Histopathologic Review of Lymph Nodes for Metastatic Breast Cancer. *Am J Surg Pathol*. 2018;42(12):1636-1646. doi:10.1097/PAS.0000000000001151

Burlina PM, Joshi N, Pekala M, Pacheco KD, Freund DE, Bressler NM. Automated grading of age-related macular degeneration from color fundus images using deep convolutional neural networks. *JAMA Ophthalmol*. 2017;135(11):1170-1176. doi:10.1001/jamaophthalmol.2017.3782

Abràmoff MD, Lavin PT, Birch M, Shah N, Folk JC. Pivotal trial of an autonomous AI-based diagnostic system for detection of diabetic retinopathy in primary care offices. *npj Digit Med*. 2018;1(1). doi:10.1038/s41746-018-0040-6

Mori Y, Kudo SE, Misawa M, et al. Real-time use of artificial intelligence in identification of diminutive polyps during colonoscopy a prospective study. *Ann Intern Med*. 2018;169(6):357-366. doi:10.7326/M18-0249

Poplin R, Varadarajan A V., Blumer K, et al. Prediction of cardiovascular risk factors from retinal fundus photographs via deep learning. *Nat Biomed Eng.* 2018;2(3):158-164. doi:10.1038/s41551-018-0195-0

Han SS, Kim MS, Lim W, Park GH, Park I, Chang SE. Classification of the Clinical Images for Benign and Malignant Cutaneous Tumors Using a Deep Learning Algorithm. *J Invest Dermatol.* 2018;138(7):1529-1538. doi:10.1016/j.jid.2018.01.028

Haenssle HA, Fink C, Schneiderbauer R, et al. Man against Machine: Diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists. *Ann Oncol.* 2018;29(8):1836-1842. doi:10.1093/annonc/mdy166

Strodthoff N, Strodthoff C. Detecting and interpreting myocardial infarction using fully convolutional neural networks. *Physiol Meas.* 2019;40(1):1-11. doi:10.1088/1361-6579/aaf34d

Rajpurkar P, Hannun AY, Haghpanahi M, Bourn C, Ng AY. Cardiologist -Level Arrhythmia Detection with Convolutional Neural Networks. 2017. <http://arxiv.org/abs/1707.01836>.

Hoff P. Do social psychiatry and neurosciences need psychopathology - and if yes, what for? *Int Rev Psychiatry.* 2008;20(6):515-520. doi:10.1080/09540260802564797

Lisdahl KM. *Frontiers in Psychiatry.* Vol 4 . ; 2010. <https://doaj.org/article/bd3a86e1c3c242b4ba60bfed56fc2a3e?>

Prata D, Mechelli A, Kapur S. Clinically meaningful biomarkers for psychosis: A systematic and quantitative review. *Neurosci Biobehav Rev.* 2014;45:134-141. doi:10.1016/j.neubiorev.2014.05.010

Atkinson AJ, Colburn WA, DeGruttola VG, et al. Biomarkers and surrogate endpoints: Preferred definitions and conceptual framework. *Clin Pharmacol Ther.* 2001;69(3):89-95. doi:10.1067/mcp.2001.113989

American Psychiatric Association. *Diagnostic and Statistical Manual of Mental Disorders (DSM-5).*; 2013.

Choong-Wan Woo¹ LJC. Building better biomarkers: brain models in translational neuroimaging. *Physiol Behav.* 2017;176(3):139-148.doi:10.1016/j.physbeh.2017.03.040

Tang CC et al. Differential diagnosis of parkinsonism: a metabolic imaging study using pattern analysis. *Lancet Neurol.* 2010. doi:10.1016/j.physbeh.2017.03.040

Drysdale AT, Grosenick L, Downar J, Dunlop K, Mansouri F MY et al. Resting-state connectivity biomarkers define neurophysiological subtypes of depression. *Nat Med* 2017. 2017. doi:10.1038/nm.4246

Clementz BA, Sweeney JA, Hamm JP, et al. Identification of Distinct Psychosis Biotypes Using Brain-Based Biomarkers. *Am J Psychiatry.* 2016. doi:10.1176/appi.ajp.2015.14091200

Price RB, Lane S, Gates K, et al. Parsing Heterogeneity in the Brain Connectivity of Depressed and Healthy Adults During Positive Mood. 2017;81(4):347-357.doi:10.1016/j.biopsych.2016.06.023

Bzdok D, Meyer-Lindenberg A. Machine Learning for Precision Psychiatry: Opportunities and Challenges. *Biol Psychiatry Cogn Neurosci Neuroimaging.* 2018;3(3):223-230. doi:10.1016/j.bpsc.2017.11.007

Suk H Il, Lee SW, Shen D. Latent feature representation with stacked auto-encoder for AD/MCI diagnosis. *Brain Struct Funct.* 2015;220(2):841-859. doi:10.1007/s00429-013-0687-3

Davatzikos C, Xu F, An Y, Fan Y, Resnick SM. Longitudinal progression of Alzheimers-like patterns of atrophy in normal older adults:

The SPARE-AD index. *Brain*. 2009;132(8):2026-2035. doi:10.1093/brain/awp091

Kohlstadt I, Amen D. Spatial patterns of brain atrophy in MCI patients, identified via high-dimensional pattern classification, predict subsequent cognitive decline Yong. *Neuroimage*. 2008;39(4):483-500. doi:10.1016/j.neuroimage.2007.10.031

Mechelli A, Prata D, Kefford C, Kapur S. Predicting clinical response in people at ultra-high risk of psychosis: a systematic and quantitative review. *Drug Discov Today*. 2015;20(8):924-927. doi:10.1016/j.drudis.2015.03.003

Hahn T, Kircher T, Straube B, et al. Predicting treatment response to cognitive behavioral therapy in panic disorder with agoraphobia by integrating local neural information. *JAMA Psychiatry*. 2015;72(1):68-74. doi:10.1001/jamapsychiatry.2014.1741

Arun V, Prajwal V, Krishna M, Arunkumar B V., Padma SK, Shyam V. A Boosted Machine Learning Approach for Detection of Depression. *Proc 2018 IEEE Symp Ser Comput Intell SSCI 2018*. 2019:41-47. doi:10.1109/SSCI.2018.8628945

Choi SB, Lee W, Yoon JH, Won JU, Kim DW. Ten-year prediction of suicide death using Cox regression and machine learning in a nationwide retrospective cohort study in South Korea. *J Affect Disord*. 2018;231(June 2017):8-14. doi:10.1016/j.jad.2018.01.019

Fernandes AC, Dutta R, Velupillai S, Sanyal J, Stewart R, Chandran D. Identifying Suicide Ideation and Suicidal Attempts in a Psychiatric Clinical Research Database using Natural Language Processing. *Sci Rep*. 2018;8(1):1-10. doi:10.1038/s41598-018-25773-2

Jackson RG, Patel R, Jayatilleke N, et al. Natural language processing to extract symptoms of severe mental illness from clinical text: The Clinical Record Interactive Search Comprehensive Data Extraction

(CRIS-CODE) project. *BMJ Open*. 2017;7(1):1-10. doi:10.1136/bmjopen-2016-01201

Proudfoot J, Goldberg D, Mann A, Everitt B, Marks I, Gray JA. Computerized, interactive, multimedia cognitive-behavioural program for anxiety and depression in general practice. *Psychol Med*. 2003;33(2):217-227. doi:10.1017/S0033291702007225

Alvarez-Jimenez M, Bendall S, Lederman R, et al. On the HORYZON: Moderated online social therapy for long-term recovery in first episode psychosis. *Schizophr Res*. 2013;143(1):143-149. doi:10.1016/j.schres.2012.10.009

Rice S, Gleeson J, Davey C, et al. Moderated online social therapy for depression relapse prevention in young people: pilot study of a 'next generation' online intervention. *Early Interv Psychiatry*. 2018;12(4):613-625. doi:10.1111/eip.12354

Bain EE, Shafner L, Walling DP, et al. Use of a Novel Artificial Intelligence Platform on Mobile Devices to Assess Dosing Compliance in a Phase 2 Clinical Trial in Subjects With Schizophrenia. *JMIR mHealth uHealth*. 2017;5(2):e18. doi:10.2196/mhealth.7030

Aldarwish MM, Ahmad HF. Predicting Depression Levels Using Social Media Posts. *Proc - 2017 IEEE 13th Int Symp Auton Decentralized Syst ISADS 2017*. 2017:277-280. doi:10.1109/ISADS.2017.41

Bedi G, Carrillo F, Cecchi GA, et al. Automated analysis of free speech predicts psychosis onset in high-risk youths. *npj Schizophr*. 2015;1(1). doi:10.1038/npjschz.2015.30

Gilvary C, Madhukar N, Elkhader J, Elemento O. The Missing Pieces of Artificial Intelligence in Medicine. *Trends Pharmacol Sci*. 2019;40(8):555-564. doi:10.1016/j.tips.2019.06.00133

Chin-Yee B, Upshur R. Three problems with big data and artificial intelligence in medicine. *Perspect Biol Med.* 2019;62(2):237-256. doi:10.1353/pbm.2019.0012

Chen JH, Asch SM, Alto P. Machine Learning and Prediction in Medicine – Beyond the Peak of Inflated Expectations. *N Engl J Med.* 2018;376(26):2507-2509. doi:10.1056/NEJMp1702071.Machine

Miotto R, Li L, Kidd BA, Dudley JT. Deep patient: an unsupervised representation to predict the future of patients from the electronic health records. *Sci Rep.* 2016 May 17;6(1):e26094.

Knight W. The dark secret at the heart of AI. *MIT Technol Rev.* 2017;1-15.

US Department of Health and Human Services. The National Institutes of Health. All of Us Research Program [Internet]. Bethesda, GA: The National Institutes of Health; 2020 [cited 2020 Feb 10]. Available from: <https://allofus.nih.gov/>

Topol EJ. Individualized medicine from prewomb to tomb. *Cell.* 2014 Mar;157(1):241-53.

Mathur S, Sutton J. Personalized medicine could transform healthcare. *Biomed Reports.* 2017;7(1):3-5.

Prainsack B. Personalized medicine: empowered patients in the 21st century? New York, NY: New York University Press; 2018.

The Guardian. Karim: the AI delivers psychological support to Syrian refugees [Internet]. London: The Guardian; 2016 [cited 2020 Feb 11]. Available from: <https://www.theguardian.com/technology/2016/mar/22/karim-the-ai-delivers-psychological-support-to-syrian-refugees>

Ardila D, Kiraly AP, Bharadwaj S, Choi B, Reicher JJ, Peng L, et al. End-to-end lung cancer screening with three-dimensional deep lear-

ning on low-dose chest computed tomography. *Nat Med.* 2019 Jun 20;25(6):954–61.

New Zealand. University of Auckland. World-first virtual pregnant uterus [Internet]. Auckland: The University of Auckland; 2018 [cited 2020 Feb 13]. Available from: <https://www.auckland.ac.nz/en/news/2018/11/08/world-first-virtual-pregnancy-wins-top-marsden-funding-.html>

IBM Watson Health. Making progress in health, together [Internet]. Cambridge, MA: IBM Watson Health; 2020 [cited 2020 Feb 13]. Available from: <https://www.ibm.com/watson-health>

IBM Watson Health. IBM Watson for oncology [Internet]. Cambridge, MA: IBM Watson Health; 2020 [cited 2020 Feb 12]. Available from: <https://www.ibm.com/products/clinical-decision-support-oncology>

IBM Watson Health. IBM Watson for drug discovery [Internet]. Cambridge, MA: IBM Watson Health; 2020 [cited 2020 Feb 12]. Available from: <https://www.ibm.com/products/watson-drug-discovery>

Tyto Care. Tyto Care: your on demand medical exam [Internet]. New York, NY: Tyto Care; 2020 [cited 2020 Feb 13]. Available from: <https://www.tytocare.com>

Sweetch Health. Sweetch: outsmarting chronic disease: empowering healthier lives [Internet]. New York, NY: Sweetch Health; 2020 [cited 2020 Feb 13]. Available from: <https://sweetch.com>

Surgical Theater. Surgical Theater: let's walk inside your brain [Internet]. Los Angeles, CA: Surgical Theater; 2020 [cited 2020 Feb 13]. Available from: <https://www.surgicaltheater.net>

DeepMind. AI could be one of humanity's most useful inventions [Internet]. London: DeepMind; 2020 [cited 2020 Oct 12]. Available from: <https://deepmind.com/about>

Topol EJ. High-performance medicine: the convergence of human and artificial intelligence. Nat Med. 2019;25(1):44-56.

ÍNDICE REMISSIVO

A

Aprendizagem 16, 17, 18, 22, 23, 24, 25, 28, 33, 44, 46, 47, 48, 49, 52, 53

Artificial 13, 16, 17, 18, 19, 22, 23, 24, 25, 29, 30, 43, 44, 52, 53, 54, 55,
56, 61, 63, 65

D

Dados 13, 16, 17, 18, 21, 23, 24, 26, 30, 31, 32, 33, 34, 35, 38, 39, 42, 43,
48, 52, 53

Diagnóstico 13, 28, 29, 30, 31, 38, 44, 46, 47, 52, 53

I

Informação 16, 17, 18, 21, 23, 25, 26, 28, 30, 43, 47, 48, 49

Inteligência 13, 16, 17, 18, 19, 23, 24, 25, 29, 30, 43, 44, 52, 53, 65

M

Máquina 13, 16, 17, 22, 23, 24, 25, 32, 33, 46, 47, 49, 53

Médicos 13, 17, 18, 20, 28, 30, 31, 32, 35, 38, 43, 52

P

Pacientes 20, 29, 30, 31, 38, 43, 44, 47, 48, 49, 50, 52

S

Saúde 13, 16, 17, 19, 20, 25, 28, 30, 31, 32, 33, 34, 35, 36, 38, 39, 42, 43,
45, 52, 53

T

Tecnologia 16, 20, 21, 28, 31, 32, 35, 36, 38, 52, 53, 65

O USO DA INTELIGÊNCIA ARTIFICIAL NA MEDICINA MODERNA



RFB Editora
Home Page: www.rfbeditora.com
Email: adm@rfbeditora.com
WhatsApp: 91 98885-7730
CNPJ: 39.242.488/0001-07
Av. Governador José Malcher, nº 153, Sala 12,
Nazaré, Belém-PA, CEP 66035065

